18.10.2004

# 日本国特許庁 JAPAN PATENT OFFICE

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出願年月日 Date of Application:

2003年11月17日

出 願 番 号 Application Number:

人

特願2003-386702

[ST. 10/C]:

[JP2003-386702]

出 願
Applicant(s):

日本電気株式会社

REC'D 0 4 NOV 2004

WIPO PCT

PRIORITY DOCUMENT

SUBMITTED OR TRANSMITTED IN COMPLIANCE WITH RULE 17.1(a) OR (b)

特許庁長官 Commissioner, Japan Patent Office 2004年 9月29日

1) 1



**BEST AVAILABLE COPY** 



【書類名】 特許願 34103834 【整理番号】 平成15年11月17日 【提出日】 殿 【あて先】 特許庁長官 【国際特許分類】 G06F 17/60 【発明者】 東京都港区芝五丁目7番1号 日本電気株式会社内 【住所又は居所】 【氏名】 襲田 勉 【発明者】 東京都港区芝五丁目7番1号 日本電気株式会社内 【住所又は居所】 山下 慶子 【氏名】 【特許出願人】 【識別番号】 000004237 日本電気株式会社 【氏名又は名称】 【代理人】 【識別番号】 100123788 【弁理士】 【氏名又は名称】 宮崎 昭夫 【電話番号】 03-3585-1882 【選任した代理人】 【識別番号】 100088328 【弁理士】 【氏名又は名称】 金田 暢之 【選任した代理人】 【識別番号】 100106297 【弁理士】 【氏名又は名称】 伊藤 克博 【選任した代理人】 【識別番号】 100106138 【弁理士】 【氏名又は名称】 石橋 政幸 【手数料の表示】 【予納台帳番号】 201087 【納付金額】 21,000円 【提出物件の目録】 【物件名】 特許請求の範囲 1 明細書 1 【物件名】 図面 1 【物件名】 【物件名】 要約書 1 【包括委任状番号】 0304683



#### 【書類名】特許請求の範囲

#### 【請求項1】

ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして 前記既知データの集合と前記未知データの集合とを格納する記憶装置と、複数の学習機械 とを使用する能動学習方法であって、

前記複数の学習機械が、前記既知データに関し、前記記憶装置からそれぞれ独立にサンプリングを行った後に学習を行う段階と、

前記学習の結果として、前記複数の学習機械の出力結果を統合して出力する段階と、 前記複数の学習機械が、前記記憶装置から未知データを取り出して予測を行う段階と、 前記予測の結果に基づいて次に学習すべきデータを計算して出力する段階と、

前記次に学習すべきデータに対応するラベル値を入力する段階と、

前記ラベル値が入力されたデータを前記未知データの集合から削除して前記既知データの集合に追加する段階と、

を有し、

前記既知データをサンプリングするとき、前記複数の学習機械による学習の結果を統合するとき、及び、前記複数の学習機械による予測から次に学習すべきデータを計算するとき、のうちの少なくとも1つにおいて、均等でない重み付けを実行する、能動学習方法。

#### 【請求項2】

前記既知データ及び前記未知データにおいてグループ分けを行う段階をさらに有し、前 記次に学習すべきデータを計算する際に、グループで散らばるようにデータを選択する、 請求項1に記載の能動学習方法。

#### 【請求項3】

前記既知データ及び前記未知データにおいてグループ分けを行う段階をさらに有し、前記予測を行う段階において、グループで散らばるように前記各学習機械に前記未知データを供給する、請求項1に記載の能動学習方法。

#### 【請求項4】

ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして 前記既知データの集合と前記未知データの集合とを格納する記憶装置と、

既知データの学習及び未知データの予測を行う複数の学習機械と、

前記学習機械ごとに設けられ、前記記憶装置から前記既知データをサンプリングして対応する学習機械に入力する複数のサンプリング装置と、

前記各学習機械が前記既知データに基づいて行った学習の結果を統合する第1の統合手段と、

前記各学習機械が前記未知データに基づいて行った予測の結果から次に学習すべきデータを計算して出力する第2の統合手段と、

前記次に学習すべきデータに対応するラベル値を入力する結果入力手段と、

前記ラベル値が入力されたデータを前記未知データの集合から削除して前記既知データの集合に追加する制御手段と、

前記サンプリング装置ごとにサンプリング時の重みを設定するサンプリング重み付け手段と、

を有する能動学習システム。

#### 【請求項5】

ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして 前記既知データの集合と前記未知データの集合とを格納する記憶装置と、

既知データの学習及び未知データの予測を行う複数の学習機械と、

前記学習機械ごとに設けられ、前記記憶装置から前記既知データをサンプリングして対応する学習機械に入力する複数のサンプリング装置と、

前記各学習機械が前記既知データに基づいて行った学習の結果を統合する第1の統合手段と、

前記各学習機械が前記未知データに基づいて行った予測の結果から次に学習すべきデー

2/



タを計算して出力する第2の統合手段と、

前記次に学習すべきデータに対応するラベル値を入力する結果入力手段と、

前記ラベル値が入力されたデータを前記未知データの集合から削除して前記既知データの集合に追加する制御手段と、

前記第1の統合手段で前記学習の結果を統合する際に用いられる重みを設定する予測重 み付け手段と、

を有する、能動学習システム。

#### 【請求項6】

前記第1の統合手段で前記学習の結果を統合する際に用いられる重みを設定する予測重 み付け手段を有する、請求項4に記載の能動学習システム。

#### 【請求項7】

ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして 前記既知データの集合と前記未知データの集合とを格納する記憶装置と、

既知データの学習及び未知データの予測を行う複数の学習機械と、

前記学習機械ごとに設けられ、前記記憶装置から前記既知データをサンプリングして対応する学習機械に入力する複数のサンプリング装置と、

前記各学習機械が前記既知データに基づいて行った学習の結果を統合する第1の統合手段と、

前記各学習機械が前記未知データに基づいて行った予測の結果から次に学習すべきデータを計算して出力する第2の統合手段と、

前記次に学習すべきデータに対応するラベル値を入力する結果入力手段と、

前記ラベル値が入力されたデータを前記未知データの集合から削除して前記既知データの集合に追加する制御手段と、

前記第2の統合手段で次に学習すべきデータを選択する際に用いられる重みを設定する データ重み付け手段と、

を有する、能動学習システム。

#### 【請求項8】

前記第2の統合手段で次に学習すべきデータを選択する際に用いられる重みを設定する データ重み付け手段を有する、請求項4乃至6のいずれか1項に記載の能動学習システム

#### 【請求項9】

前記既知データ及び前記未知データにおいてグループ分けを行うグループ生成手段をさらに有し、

前記第2の統合手段は前記次に学習すべきデータを計算する際に、グループで散らばるようにデータを選択する、請求項4乃至8のいずれか1項に記載の能動学習システム。

#### 【請求項10】

前記既知データ及び前記未知データにおいてグループ分けを行うグループ生成手段と、 グループで散らばるように前記各学習機械に前記未知データを供給するデータ選択手段と をさらに有する、請求項4乃至8のいずれか1項に記載の能動学習システム。

#### 【請求項11】

ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして 前記既知データの集合と前記未知データの集合とを格納する記憶装置と、

既知データの学習及び未知データの予測を行う複数の学習機械と、

前記学習機械ごとに設けられ、前記記憶装置から前記既知データをサンプリングして対応する学習機械に入力する複数のサンプリング装置と、

前記各学習機械が前記既知データに基づいて行った学習の結果を統合する第1の統合手段と、

前記各学習機械が前記未知データに基づいて行った予測の結果から次に学習すべきデータを計算して出力する第2の統合手段と、

前記次に学習すべきデータに対応するラベル値を入力する結果入力手段と、

3/



前記ラベル値が入力されたデータを前記未知データの集合から削除して前記既知データの集合に制御手段と、

前記既知データ及び前記未知データにおいてグループ分けを行うグループ生成手段と、 を有し、前記第2の統合手段は前記次に学習すべきデータを計算する際に、グループで 散らばるようにデータを選択する、能動学習システム。

#### 【請求項12】

ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして 前記既知データの集合と前記未知データの集合とを格納する記憶装置と、

既知データの学習及び未知データの予測を行う複数の学習機械と、

前記学習機械ごとに設けられ、前記記憶装置から前記既知データをサンプリングして対応する学習機械に入力する複数のサンプリング装置と、

前記各学習機械が前記既知データに基づいて行った学習の結果を統合する第1の統合手 段と、

前記各学習機械が前記未知データに基づいて行った予測の結果から次に学習すべきデータを計算して出力する第2の統合手段と、

前記次に学習すべきデータに対応するラベル値を入力する結果入力手段と、

前記ラベル値が入力されたデータを前記未知データの集合から削除して前記既知データの集合に制御手段と、

前記既知データ及び前記未知データにおいてグループ分けを行うグループ生成手段と、 グループで散らばるように前記各学習機械に前記未知データを供給するデータ選択手段 と、

を有する、能動学習システム。

#### 【請求項13】

コンピュータを、

ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして 前記既知データの集合と前記未知データの集合とを格納する記憶手段、

前記記憶手段から既知データをサンプリングするとともに既知データの学習及び未知データの予測を行う複数の学習手段、

前記各学習機械が前記既知データに基づいて行った学習の結果を統合する第1の統合手段、

前記各学習手段が前記未知データに基づいて行った予測の結果から次に学習すべきデータを計算して出力する第2の統合手段、

前記次に学習すべきデータに対応するラベル値を入力する結果入力手段、

前記ラベル値が入力されたデータを前記未知データの集合から削除して前記既知データの集合に追加する制御手段、

前記サンプリング装置でのサンプリング時の重み、前記第1の統合手段で用いられる重み、及び前記第2の統合手段で用いられる重みのうちの少なくとも1つの重みを設定する重み付け手段、

として機能させるプログラム。

#### 【請求項14】

前記コンピュータをさらに、前記既知データ及び前記未知データにおいてグループ分けを行うグループ生成手段として機能させ、前記第2の統合手段において前記次に学習すべきデータを計算する際に、グループで散らばるようにデータが選択されるようにする、請求項13に記載のプログラム。

#### 【請求項15】

前記コンピュータをさらに、

前記既知データ及び前記未知データにおいてグループ分けを行うグループ生成手段、 グループで散らばるように前記各学習機械に前記未知データを供給するデータ選択手段

として機能させる請求項13に記載のプログラム。



## 【請求項16】

コンピュータが読み取り可能な記録媒体であって、請求項13乃至15のいずれか1項に記載のプログラムを格納した記録媒体。



#### 【書類名】明細書

【発明の名称】能動学習方法およびシステム

#### 【技術分野】

#### [0001]

本発明は、能動学習方法及び能動学習システムに関する。

#### 【背景技術】

#### [0002]

能動学習とは、非特許文献1に記載されたところによれば、学習者が学習データを能動的に選択することにできる学習形態であり、一般に学習を能動的に行うことにより、データ数や計算量の意味で学習の効率性を向上することができることが知られている。能動学習を行うシステムを能動学習システムと呼ぶ。例えば、集められたデータに対して統計的に分析を行い、ラベル値が未知のデータに対しては、過去のデータの傾向から結果の予測を行うような学習システムを考える。そのような学習システムには、能動学習システムを適用することができる。以下、この種の能動学習システムの概略を説明する。

#### [0003]

ラベル値が未知のデータとラベル値が既知のデータが存在するものとする。ラベル値が 既知のデータで学習を行い、その学習した結果をラベル値が未知のデータに適用する。そ のときに、ラベル値が未知のデータから効率的に学習を行えるようなデータを学習システムが選択し、そのデータを出力する。出力されたデータに対して実験するなり調査するな りして、ラベル値が未知のデータに対する結果を得て、それを入力したのちラベル値が既 知のデータに混ぜて、同じように学習を行う。その一方で、ラベル値が未知のデータの集 合からは、結果が得られたデータを削除する、というものである。能動学習システムでは 、そのような動作を繰り返して行っていく。

#### [0004]

また、データは以下のように記述されている。1つのデータは、複数の属性とラベルというもので記述される。たとえば有名な評価データの中には、"golf"というものがある。それはゴルフをプレーするかしないかを判定するものであって、天気、温度、湿度、風の強さという4つのものから記述されている。天気は、「晴れ」、「曇り」または「雨」、風は、「有」または「無」という値をとる。気温と湿度は実数値である。たとえば1つのデータは、天気:晴れ、温度:15度、湿度:40%、風:無、プレー:する、というように書かれている。そのデータの場合、天気、温度、湿度、風の4つを属性と呼ぶ。また、プレーする、しないという結果のことをラベルと呼ぶ。本明細書では、ラベルがとりうる値が離散値の場合には、特にクラスと呼ぶ。

#### [0005]

ここで、さまざまな用語を定義しておく。

#### [0006]

仮にラベルは2値であるとしておく。その2値のうち注目しているラベルの方を正例、 それ以外のものを負例とする。またラベルが多値の場合には、注目している1つのラベル 値を正例、それ以外のすべてのラベル値を負例とする。またラベルがとりうる値が連続値 の場合には注目する値付近にラベル値が存在するとき正例と呼び、それ以外のところにあ るときに負例と呼ぶことにする。

#### [0007]

学習の精度を測る指標としては、ROC(受信者動作特性: receiver operating chara cteristic) 曲線、ヒット率、正解率の推移などがある。以下の説明では、これら3つの指標を用いて評価を行う。

#### [0008]

ROC曲線は、以下のように定義される。

横軸:負例のうち正例と判断されたデータの個数/全負例数,

縦軸:正例のうち正例と判断されたデータの個数/全正例数.

ランダムな予測を行ったとき、ROC曲線は、原点と(1, 1)を結ぶ対角線となる。



#### [0009]

ヒット率は以下のように定義される。

横軸:ラベル値が既知のデータ数/(ラベル値が未知+既知のデータ数),

縦軸:ラベル値が既知のデータの中の正例数/全正例数.

ランダムな予測を行ったとき。ヒット率は、原点と(1,1)を結ぶ対角線となる。また、限界は原点と(正例数/(ラベル値が未知+既知のデータ数),1)を結んだ線となる。

#### [0010]

正解率の推移は以下のように定義される。

横軸:ラベル値が既知のデータ数,

縦軸:正しく判断されたデータの個数/ラベル値が既知のデータ数.

後述する「発明を実施するための最良の形態」においては、これらの指標を用いて、本発明による能動学習システムを評価している(図3、5、7、9、11、13、15、18を参照)。

#### [0011]

またエントロピーとは、以下のように定義される。各P\_iはiである確率を示しているとする。

#### [0012]

エントロピー=- (p\_1\*log (P\_1) +p\_2\*log (P\_2) +…+P\_n\*log (P\_n))

なお、従来の能動学習システムを開示するものとしては、特開平11-316754号 公報 (特許文献1)に開示されたものがある。この公報に開示の能動学習システムは、学習の精度を向上するために、下位アルゴリズムに学習を行わせる学習段階と、学習精度を ブースティングにより向上させるブースティング段階と、複数の入力候補点に対する関数 値予測段階と、重みの総和が最大の出力値の重み和と、重みの総和が次に大きい出力値の重み和との差が最も小さいような入力点を選択する入力点指定段階と、を行うことを特徴とするものである。

#### [0013]

また、非特許文献 1 ( "発見科学とデータマイニング" , 共立出版、2001年6月、pp. 64-71) には、複数の学習機械を備えるシステムを使用し、各学習機械はデータからランダムにサンプリングしてそのデータを学習し、ラベル値が未知のデータに対してはそれぞれの学習機械が予測を行ってもっとも分散が大きくなるような点を次に学習すべき点として出力するような手法を開示している。

【特許文献1】特開平11-316754号公報

【非特許文献1】 "発見科学とデータマイニング", 森下真一・宮野 悟編、共立出版、2001年6月、ISBN4-320-12018-3、pp. 64-71

#### 【発明の開示】

【発明が解決しようとする課題】

#### [0014]

しかしながら上述した従来の手法は、次に学習すべきデータとして出力するものをユーザーの意思で制御できない、という問題点を有する。その理由は、これらの従来の手法は、なるべく早く学習精度を向上することを目標とするために、次の候補点として最も分散の大きな点や、下位の学習機械からの出力が割れる点のみを選んでいるからである。

#### [0015]

これらの従来の手法は、学習データにおいて、対象となる値やクラスのデータ数が他のクラスや値のものに比べてきわめて低い状況下において、対象となっている値やクラスの正解率を得るのが困難である、という問題点を有する。その理由は、今までに開発されてきた下位学習アルゴリズムが極端な個数の不平等な状況までを考察して設計されたものでないことにあるばかりでなく、従来の能動学習アルゴリズムも同じようにそのような状況を想定していないことにある。

3/



#### [0016]

またこれらの従来の手法が用いる能動学習アルゴリズムは、入力すべきデータの選択の 段階において、似たようなデータを入力点として数多く出力してしまう、という問題点が ある。その理由もやはり、従来の能動学習アルゴリズムが、下位の学習アルゴリズムが学 習したものを十分に活かしきるようなメカニズムを有していないことにある。

#### [0017]

さらにこれらの従来の手法は、システムにおいて最終判断の方法が予め定められている ために、学習の精度を変えられない、という問題点も有する。

#### [0018]

そこで本発明の目的は、能動学習法の精度を向上させつつ、利用者の意思で精度を制御することができ、また、興味のあるデータを先に抜き出すという機能なども備える能動学習方法及びシステムを提供することにある。

#### 【課題を解決するための手段】

#### [0019]

本発明の能動学習方法は、ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして既知データの集合と未知データの集合とを格納する記憶装置と、複数の学習機械とを使用する能動学習方法であって、複数の学習機械が、既知データに関し、記憶装置からそれぞれ独立にサンプリングを行った後に学習を行う段階と、学習の結果として、複数の学習機械の出力結果を統合して出力する段階と、複数の学習機械が、記憶装置から未知データを取り出して予測を行う段階と、予測の結果に基づいて次に学習すべきデータを計算して出力する段階と、次に学習すべきデータに対応するラベル値を入力する段階と、ラベル値が入力されたデータを未知データの集合から削除して既知データの集合に追加する段階と、を有し、既知データをサンプリングするとき、複数の学習機械による学習の結果を統合するとき、及び、複数の学習機械による予測から次に学習すべきデータを計算するとき、のうちの少なくとも1つにおいて、均等でない重み付けを実行する。

#### [0020]

本発明の能動学習方法における重み付けでは、例えば、データ数に極端に偏りが発生しているときに、その比重を重くするようにする。さらにこの方法では、次に予測のために学習装置に入力すべきデータの選択において、選ばれてきた候補のデータの中から空間的なデータの分布を考慮に入れながらさらに選び出すというデータの分布に広がりを持たせる機構を付け加えることによって、お互いに似たようなデータを出力することを避けることができる。

#### [0021]

本発明の能動学習システムは、ラベル値が既知のデータを既知データとしラベル値が未知のデータを未知データとして既知データの集合とを格納する記憶装置と、既知データの学習及び未知データの予測を行う複数の学習機械と、学習機械ごとに設けられ、記憶装置から既知データをサンプリングして対応する学習機械に入力する複数のサンプリング装置と、各学習機械が既知データに基づいて行った学習の結果を統合する第1の統合手段と、各学習機械が既知データに基づいて行った学習の結果を統合する第1の統合手段と、各学習機械が表知データに基づいて行った予測の結果から次に学習すべきデータに対応するラベル値を入力する結果入力手段と、ラベル値が入力されたデータを未知データの集合から削除して既知データの集合に追加する制御手段と、を有するとともに、(1)サンプリング装置ごとにサンプリング時の重みを設定するサンプリング重み付け手段、(2)第1の統合手段で学習の結果を統合する際に用いられる重みを設定する予測重み付け手段、(3)第2の統合手段で次に学習すべきデータを選択する際に用いられる重みを設定するデータ重み付け手段、及び(4)既知データ及び未知データにおいてグループ分けを行うグループ生成手段のうちの少なくとも1つを有する。

#### [0022]

本発明の能動学習システムにおける重み付けでは、例えば、データ数に極端に偏りが発出証特2004-3087146



生しているときに、その比重を重くするようにする。

#### 【発明の効果】

[0023]

本発明によれば、(1)学習データをサンプリングする際にデータに重み付けを行う、(2)入力候補点から入力点を選び出す際にデータに重み付けを行う、及び(3)入力されたデータに対して予測を行う際にデータに重み付けを行う、の計3通りの重み付けのうちの少なくとも1つを採用することにより、以下のような効果が得られる。

#### [0024]

まず第1に、対象となっているデータの重みを重くすることで重点的に学習を行うことができるので、対象となっているデータの、全体に対する割合が極めて低い状況下において、マイニングの精度を向上させながら、カバー率を向上させることができる。

#### [0025]

第2に、対象となっているデータの重みを軽くすることで、対象となっているものが未 発見の領域の学習を行っていくことが可能になるため、対象となっているデータがさまざ まな特徴に基づいているとき、それを、早期に発見できる。

#### [0026]

第3に、従来の能動学習法がデータの予測を行うときに均等に学習結果を扱っているのに対し、本発明では重み付けすることが可能なため、重みを変えることで精度を制御することが可能になり、任意の精度で学習することが可能になる。

#### [0027]

さらに、従来の方法では次に学習すべきデータが空間的にある領域に固まる傾向にあるが、本発明では、それらのデータが空間的に散らばるような機構を設けることにより、従来の能動学習法の欠点を修正でき、正解率を従来のものよりも高めることができる。

【発明を実施するための最良の形態】

#### [0028]

次に、本発明の好ましい実施の形態について、図面を参照して詳細に説明する。本発明の能動学習システムは、(1)学習データをサンプリングする際にデータに重み付けを行う、及び(3)入力されたデータに対して予測を行う際にデータに重み付けを行う、の計3通りの重み付けのうちの少なくとも1つを採用することにより、上述した本発明の目的を達しようとするものである。これらの重み付けにおいては、データ数に極端に偏りが発生しているときに、その比重を重くするように重み付けを行っている。本発明は、どの段階で重み付けを行うかによって種々の実施形態が考えられる。

#### [0029]

また、本発明では、次に学習すべきデータを選択する際に、選ばれてきた候補のデータから空間的なデータの分布を考慮に入れながらさらに選び出すという、データの分布に広がりを持たせるメカニズムを付け加えることによって、お互いに似たようなデータを出力することを避けることができる。このようなメカニズムの有無によっても、本発明は種々の実施形態が考えられる。

#### [0030]

以下、このような各種の実施形態について説明する。

#### [0031]

#### 《第1の実施形態》

図1は、本発明の第1の実施形態の能動学習システムの構成を示している。この能動学習システムは、ラベル値が既にわかっているデータ(すなわち既知データ)を蓄えておく記憶装置101と、記憶装置101内の既知データをサンプリングする時に重み付けを行うためのデータを生成するサンプリング重み付け装置102と、予測を行う時に重み付けを行うためのデータを生成する予測重み付け装置103と、次に学習すべきデータを選択するときに重み付けを行うためのデータを生成するデータ重み付け装置104と、複数の学習機械106と、記憶装置101からデータをサンプリングして対応する学習機械10



6に対してデータを供給する複数のサンプリング装置105と、複数の学習機械106からの学習結果をまとめる規則統合装置107と、規則統合装置107に接続した出力装置111と、複数の学習機械106での結果に基づき次に学習すべきデータを計算するデータ統合装置108と、データ統合装置108に接続した出力装置112と、次に学習すべきデータの出力結果に対て結果を入力する結果入力装置113と、ラベル値がわかっていないデータ(すなわち未知データ)を格納する記憶装置109と、この能動学習システム全体の制御を行う制御装置110と、を備えている。特に制御装置110は、結果入力装置113によって入力された結果を例えば表形式のものとしてまとめ、記憶装置109内における該当するデータを削除し、その代わりに、結果が加えられたデータを記憶装置101内に格納するという制御を行う。サンプリング装置105と学習機械106とは、プリング装置105からデータが供給されるとともに、記憶装置109からは未知データが供給される。規則統合装置107に接続した出力装置111からは、学習した規則が出力される。規則統合装置108に接続した出力装置112からは、次に学習すべきデータが出力される。

#### [0032]

サンプリング重み付け装置102は、各サンプリング装置105に対して、記憶装置101に格納された既知データに基づき、サンプリング時にデータに対して重み付けを行うための重み付けデータを生成して供給する。予測重み付け装置103は、記憶装置101に格納された既知データに基づき、規則統合装置107において各学習機械106ごとの学習結果をまとめる際に重み付けを行うための重み付けデータを生成し、生成した重み付けデータを規則統合装置107に供給する。同様にデータ重み付け装置104は、記憶装置101に格納された既知データに基づき、データ統合装置108において次に学習すべきデータを選択して出力する際に重み付けを行うための重み付けデータを生成し、生成した重み付けデータをデータ統合装置108に供給する。

#### [0033]

ここで、サンプリング重み付け装置 102、予測重み付け装置 103 及びデータ重み付け装置 104 のそれぞれによる重み付けを説明する。これらの重み付け装置  $102\sim10$  4による重み付けとしては、均等でない重み付けであれば種々のものを使用できる。

#### [0034]

サンプリング重み付け装置 102 での重み付けとしては、例えば、(1)既知データにおけるクラスあるいは値に応じた重みを設定する、(2)ラベル値が離散値を取る場合に、各サンプリング装置 105 が、独立して、あるクラスのデータの全てとそれ以外のクラスのデータからランダムにサンプリングするように重みを設定する、(3)ラベル値が連続値を取る場合に、各サンプリング装置 105 が、特定のラベルの値の付近のデータの全てとそれ以外のラベル値のデータからランダムにサンプリングするように重みを設定する、などが挙げられる。

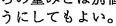
#### [0035]

予測重み付け装置103での重み付けとしては、例えば、各学習機械106が出力した 結果についてクラス(ラベル値が離散値を取る場合)ごとあるいは数値における区間(ラ ベル値が連続値を取る場合)ごとに重みを決定する方法がある。

#### [0036]

データ重み付け装置104での重み付けとしては、例えば、(1)ラベル値が離散値をとる場合にクラスごとの頻度から計算されるばらつき具合に応じて重みを割当てる、(2)各学習機械106での結果として得られる値の分散に応じて重みを割当てる、(3)ラベル値が離散値をとる場合にクラスごとの頻度から計算されるエントロピーに応じて重みを割当てる、などが挙げられる。ばらつき具合に応じて重みを割当てる場合には、ばらつき具合が最大のところのみが最大の重みになることは除くようにしてもよい。同様に、分散あるいはエントロピーに応じて重みを割当てる場合には、それら分散あるいはエントロピーが最大のところのみが最大の重みになることは除くようにしてもよい。さらに、これ





らの重みとは別個に各学習機械106で得られる結果そのものに対して重みを割当てるよ

#### [0037]

次に、本実施形態の能動学習システムの動作について、図2に示すフローチャートを利 用して説明する。ここでは、データは表形式で与えられるものとする。

#### [0038]

まず、ステップ201において、ラベル値が既知のデータは記憶装置101に、ラベル 値が未知のデータは記憶装置109に記憶される。その結果、既知データの集合が記憶装 置101に格納され、未知データの集合が記憶装置109に格納されることになる。

#### [0039]

次に、ステップ202において、サンプリング重み付け装置102は、記憶装置101 から送られてきたデータに基づいて重み(すなわち重み付けデータ)を生成し、あるいは そのような重みを読み込み、各サンプリング装置105に送る。各サンプリング装置10 5は、サンプリング重み付け装置102から送られてきた重みにしたがって重み付けを行 いながら、記憶装置101内の既知データをサンプリングし、サンプリングしたデータを 対応する学習機械106に送る。各学習機械106は、ステップ203において、サンプ リング装置から送られてきたデータに基づいて学習を実行する。

#### [0040]

記憶装置101からは予測重み付け装置103にもデータが送られており、ステップ2 04において、予測重み付け装置103は、記憶装置101から送られてきたデータに基 づいて重み(すなわち重み付けデータ)を生成し、あるいはそのような重みを読み込み、 それらを規則統合装置107へ送る。規則統合装置107は、重み付けデータに基づいて 、各学習機械106からの学習結果に重み付けを行いながらこれらの学習結果をまとめる 。このとき、各学習機械106が出力した結果についてクラス(ラベル値が離散値を取る 場合)ごとあるいは数値における区間(ラベル値が連続値を取る場合)ごとに頻度を計算 し、頻度と上述した重みとを乗算し、その値がもっとも大きな値となっているものを予想 値として出力する。規則統合装置107は、学習結果をまとめた結果を規則として出力装 置111に送る。

#### [0041]

次に各学習機械106は、ステップ205において、記憶装置109に格納されたラベ ル値が未知のデータに対して予測を行い、その結果は、データ統合装置108に送られる 。このとき、記憶装置101からはデータ重み付け装置104にもデータが送られており 、ステップ206において、データ重み付け装置104は、記憶装置101から送られて きたデータに基づいて重み(すなわち重み付けデータ)を生成し、あるいはそのような重 みを読み込み、それらをデータ統合装置108へ送る。データ統合装置108は、重み付 けデータに基づいて、各学習機械106からの予測結果に重み付けを行いながらこれらの 結果をまとめ、次に学習すべきデータを選択する。次に学習すべきデータの選択方法とし ては、以下のようなものが挙げられる。例えば、(1)ばらつき具合あるいはエントロピ ーに応じて重みが割当てられている場合には、各学習機械106が出力した結果からその クラスごとに頻度を計算し、頻度を元にばらつき具合あるいはエントロピーを示す数値を 計算し、ばらつき具合あるいはエントロピーに応じて割り当てられた重みが重い順番にデ ータを選択する、(2)分散に応じて重みが割当てられている場合には、各学習機械10 6 が出力した結果からその分散を計算し、分散に応じて割り当てられた重みが重い順番に データを選択する、(3)ばらつき具合あるいはエントロピーと結果とのそれぞれに応じ て重みが割当てられている場合には、各学習機械106が出力した結果からそのクラスご とに頻度を計算し、頻度を元にばらつき具合あるいはエントロピーを示す数値を計算し、 ばらつき具合あるいはエントロピーに応じて割り当てられた重みと結果に割り当てられた 重みとをあわせて重みの重い順番にデータを選択する、(4)分散と結果のそれぞれに応 じて重みが割当てられている場合には、各学習機械106が出力した結果からその分散を 計算し、分散に応じて割り当てられた重みと結果に割り当てられた重みとをあわせて重み

7/



の重い順番にデータを選択する。データ統合装置108は、その結果を次に学習すべきデータとして出力装置112に送る。

#### [0042]

次に、ステップ207において、次に学習すべきデータに対する結果(ラベル値)が、 結果入力装置113を介し、人手によって、あるいはコンピュータにより入力される。入 力された結果は制御装置110に送られ、制御装置110は、その結果が入力されたデー タを記憶装置109から削除し、その代わりに記憶装置101に記憶させる。

#### [0043]

以後、上述の処理が繰り返され、能動学習が進行する。この場合、これらの処理は、最長の場合で記憶装置109内に未知データがなくなるまで行われるが、その前に打ち切るようにしてもよい。後述するように本実施形態によれば、迅速に"よい結果"を得ることができるので、例えば適当な反復回数を設定してそこで処理を打ち切るようにすることができる。サンプリング重み付け装置102、予測重み付け装置103及びデータ重み付け装置104は、いずれも均等でない重み付けを行う。

#### [0044]

図3(a)~(c)は、本実施形態の能動学習システムの効果を説明する図である。図 3(a)において破線301は従来の能動学習法を用いた場合のヒット率を示し、実線3 02は、本実施形態の能動学習システムを用いた場合のヒット率を示している。本実施形 態によれば、従来の能動学習法よりも早期の段階において、対象となっているクラス(値 )のデータを見つけていることがわかる。図3(b)において、破線303は従来の能動 学習法を用いた場合のROC曲線を示し、実線304は本実施形態の能動学習システムを 用いた場合のROC曲線を示している。本実施形態によれば、従来の能動学習法に比べて 高い精度で学習を行えていることがわかる。さらに、従来の能動学習法ではどのような精 度にするのかを外部から制御することができなかったが(曲線上のある1点に存在する) 、本実施形態の手法では、予測重み付け装置103における重みを変えることで、任意の 精度(図では、A、B、C、Dと4つの直線が存在するが、任意の位置に対する例)を設 定できる。さらに図3 (c) において、破線305は従来の能動学習法を用いた場合の正 解率の推移を示し、破線306は、本実施形態の能動学習システムを用いた場合における 正解率の推移を示している。本実施形態によれば、対象となっているクラス(値)のデー タの重みを重くすることによって、そのクラスに関する正解率を上げることができること がわかる。

#### [0045]

#### 《第2の実施形態》

次に、本発明の第2の実施形態について、図4を参照して説明する。図4に示す能動学習システムは、第1の実施形態の能動学習システムと同様のものであるが、予測重み付け装置とデータ重み付け装置とが設けられていない点で、第1の実施形態のものと相違する。予測重み付け装置とデータ重み付け装置とが設けられていないことにより、規則統合装置107では、学習機械106から出てきた結果がすべて均等に取り扱われ、多数決などの手段によって最終的な規則が出力されることになる。具体的には、規則統合装置107は、各学習機械106が出力した結果についてクラス(ラベル値が離散値を取る場合)ごとの頻度を計算し、その値がもっとも大きな値となっているものを予想値として出力する。

#### [0046]

またデータ統合装置108においも同様に出力結果が均等に扱われ、もっとも判断に迷うデータが出力されることになる。具体的には、例えば、(1)ラベル値が離散値を取る場合に、各学習機械106が出力した結果からそのクラスごとに頻度を計算し、頻度を元にばらつき具合を示す数値を計算し、あるクラスと判断されたデータとばらつき具合を示す指標が最大もしくは最大付近のデータから、次に学習すべきデータを選択する。(2)ラベル値が連続値を取る場合に、各学習機械106が出力した結果からその分散を計算し、ある数値の付近にあるデータと分散が最大もしくは最大付近のデータから、次に学習す



べきデータを選択する。(3) 各学習機械106が出力した結果からその分散を計算し、特定のクラス以外のデータ(あるいはある数値付近にないデータ)であってかつ"分散が最小もしくは最小に近い"データから、次に学習すべきデータを選択する。

#### [0047]

図5は、本実施形態の能動学習システムの効果を示す図である。図において、破線307は、従来の能動学習法を用いた場合の学習精度を表すROC曲線であり、実線308は、本実施形態の能動学習システムにより、対象となっているクラス(値)のデータが多く選ばれるようなサンプリングをしたとき学習精度を示すROC曲線である。本実施形態によれば、従来の能動学習法よりも高い精度が得られることがわかる。

#### [0048]

#### 《第3の実施形態》

次に、本発明の第3の実施形態について、図6を参照して説明する。図6に示す能動学習システムは、第1の実施形態の能動学習システムと同様のものであるが、サンプリング重み付け装置とデータ重み付け装置とが設けられていない点で、第1の実施形態のものと相違する。サンプリング重み付け装置とデータ重み付け装置とが設けられていないことにより、各サンプリング装置105では既知のデータがすべて均等に取り扱われ、ランダムなサンプリングが行われる。またデータ統合装置108では、第2の実施形態の場合と同様に、出力結果が均等に扱われ、もっとも判断に迷うデータが出力されることになる。

#### [0049]

図7は、本実施形態の能動学習システムの効果を示す図であり、図において線309は、この能動学習システムの学習精度を表すROC曲線を示している。従来の能動学習法では学習結果を統合するときに均等に結果を扱っていたため、ある特定の精度でしか能動学習システムを構築することができなかった。本実施形態によれば、任意の重みで学習結果を統合することができるため、たとえばA、B、C、Dのような精度でシステムを構成することができる。

#### [0050]

#### 《第4の実施形態》

次に、本発明の第4の実施形態について、図8を参照して説明する。図8に示す能動学習システムは、第1の実施形態の能動学習システムと同様のものであるが、サンプリング重み付け装置と予測重み付け装置とが設けられていない点で、第1の実施形態のものと相違する。サンプリング重み付け装置と予測重み付け装置とが設けられていないことにより、各サンプリング装置105では既知のデータがすべて均等に取り扱われ、ランダムなサンプリングが行われる。また、規則統合装置107では、第2の実施形態の場合と同様に、学習機械106から出てきた結果がすべて均等に取り扱われ、多数決などの手段によって最終的な規則が出力されることになる。

#### [0051]

図9は、本実施形態の能動学習システムの効果を示す図である。図において、破線310は従来の能動学習法を用いた場合の正解率の推移を示し、破線311は、本実施形態の能動学習システムを用いた場合における正解率の推移を示している。本実施形態では、サンプリングのときの重みとして、次に実験すべきデータがなるべく散らばるような重み付けを行っている。このような重み付けを用いることにより、従来の能動学習法よりも早く学習していることわかる。

#### [0052]

#### 《第5の実施形態》

次に、本発明の第5の実施形態について、図10を参照して説明する。図10に示す能動学習システムは、第1の実施形態の能動学習システムと同様のものであるが、データ重み付け装置が設けられていない点で、第1の実施形態のものと相違する。データ重み付け装置が設けられていないことにより、データ統合装置108では、第2の実施形態の場合と同様に、出力結果が均等に扱われ、もっとも判断に迷うデータが出力されることになる



#### [0053]

図11は、本実施形態の能動学習システムの効果を示す図である。図において、破線312は従来の能動学習法を用いた場合のROC曲線を示し、破線313は、本実施形態の能動学習システムを用いた場合におけるROC曲線を示している。本実施形態では、サンプリング時には、あるクラス(値)の重みが重くなるような重み付けを行い、次に学習すべきデータを選択する時には、同様に、そのクラスの重みが重くなるような重み付けを行っている。図11から分かるように、本実施形態によれば、学習の精度が向上し、また、予測重み付け装置の重みを変えることで、A、B、C、Dにあるように、任意の精度で学習を行うことができるようになる。

#### [0054]

#### 《第6の実施形態》

次に、本発明の第6の実施形態について、図12を参照して説明する。図12に示す能動学習システムは、第1の実施形態の能動学習システムと同様のものであるが、予測重み付け装置が設けられていない点で、第1の実施形態のものと相違する。予測重み付け装置が設けられていないことにより、規則統合装置107では、第2の実施形態の場合と同様に、学習機械106から出てきた結果がすべて均等に取り扱われ、多数決などの手段によって最終的な規則が出力されることになる。

#### [0055]

図13(a),(b)は、本実施形態の能動学習システムの効果を示す図である。図13(a)において、破線314は従来の能動学習法を用いた場合のヒット率を示し、実線315は、本実施形態の能動学習システムを用いた場合におけるヒット率を示している。また、図13(b)において、破線316は従来の能動学習法を用いた場合のROC曲線を示し、実線317は、本実施形態の能動学習システムを用いた場合のROC曲線を示している。本実施形態においては、サンプリング時には、あるクラス(値)の重みが重くなるように重み付けを行っており、次に学習すべきデータを選択するときも、同様に、そのクラスの重みが重くなるように重み付けを行っている。本実施形態によれば、対象となるクラス(値)の9割を従来のものよりも早く発見でき、また、学習精度も向上していることがわかる。

#### [0056]

#### 《第7の実施形態》

次に、本発明の第7の実施形態について、図14を参照して説明する。図14に示す能動学習システムは、第1の実施形態の能動学習システムと同様のものであるが、サンプリング重み付け装置が設けられていない点で、第1の実施形態のものと相違する。サンプリング重み付け装置が設けられていないことにより、各サンプリング装置105では既知のデータがすべて均等に取り扱われ、ランダムなサンプリングが行われる。

#### [0057]

図15(a),(b)は、本実施形態の能動学習システムの効果を示す図である。図15(a)において、破線318は従来の能動学習法を用いた場合のヒット率を示している。図15(b)において、破線320は、本実施形態の能動学習システムを用いた場合におけるROC曲線を示している。本実施形態では、次に学習すべきデータを選択するときの重み付けも、学習結果を統合するときの重み付けも、あるクラス(値)のデータの重みが重くなるようにした。本実施形態によれば、重みを重くしたクラスのデータが早く出力されており、また図示A、B、C、Dに示されるように、任意の精度で学習を行えるようになっている。

#### [0058]

#### 《第8の実施形態》

次に、本発明の第8の実施形態について、図16を参照して説明する。図16に示す能動学習システムは、第1の実施形態の能動学習システムと同様のものであるが、グループ生成装置115が付加されているとともに、データ統合装置とそのデータ統合装置に接続



する出力装置とがデータ統合選択装置 114 で置き換えられている点で相違する。データ統合選択装置 114 は、第1 の実施形態のシステム(図1 参照)におけるデータ統合装置 108 と出力装置 112 の機能を合わせ持つものであるが、次に学習すべきデータを選択する際に、グループ生成装置 115 でのグループ分けにしたがって、相互のデータがなるべくグループに散らばるように選択する。グループ選択装置 114 は、記憶装置 101 に格納されたラベル値が既知のデータ、または記憶装置 109 に格納されたラベル値が未知のデータ、もしくはその両者のデータをグループ分けするものである。

#### [0059]

次に、本実施形態の能動学習システムの動作について、図17に示すフローチャートを 利用して説明する。ここでは、データは表形式で与えられるものとする。

#### [0060]

まず、ステップ211において、ラベル値が既知のデータは記憶装置101に、ラベル値が未知のデータは記憶装置109に記憶される。グループ生成装置115は、ステップ212において、記憶装置101内の既知データと記憶装置109内の未知データに関してグループ分けを行う。グループ分けの結果は、グループ生成装置115からグループ情報として出力される。

#### [0061]

次に、ステップ213において、サンプリング重み付け装置102は、記憶装置101から送られてきたデータに基づいて重み(すなわち重み付けデータ)を生成し、あるいはそのような重みを読み込み、各サンプリング装置105に送る。各サンプリング装置105は、サンプリング重み付け装置102から送られてきた重みにしたがって重み付けを行いながら、記憶装置101内の既知データをサンプリングし、サンプリングしたデータを対応する学習機械106に送る。各学習機械106は、ステップ214において、サンプリング装置から送られてきたデータに基づいて学習を実行する。

#### [0062]

記憶装置101からは予測重み付け装置103にもデータが送られており、ステップ2 15において、予測重み付け装置103は、記憶装置101から送られてきたデータに基 づいて重み(すなわち重み付けデータ)を生成し、あるいはそのような重みを読み込み、 それらを規則統合装置107へ送る。規則統合装置107は、重み付けデータに基づいて 、各学習機械106からの学習結果に重み付けを行いながらこれらの学習結果をまとめる 。規則統合装置107は、学習結果をまとめた結果を規則として出力装置111に送る。

#### [0063]

次に各学習機械106は、ステップ216において、記憶装置109に格納されたラベル値が未知のデータに対して予測を行い、その結果は、データ統合選択装置114に送られる。

#### [0064]

このとき、記憶装置101からはデータ重み付け装置104にもデータが送られており、ステップ217において、データ重み付け装置104は、記憶装置101から送られてきたデータに基づいて重み(すなわち重み付けデータ)を生成し、あるいはそのような重みを読み込み、それらをデータ統合選択装置114へ送る。データ統合選択装置114は、重み付けデータとグループ生成装置115からのグループ情報とに基づき、各学習機械106からの予測結果に重み付けを行いながらこれらの結果をまとめ、次に学習すべきデータを選択する。その際、データ統合選択装置114は、グループ生成装置814でのグループ分けにしたがって、お互いのデータがなるべくグループに散らばるように、次に学習すべきデータをする。

#### [0065]

次に、ステップ218において、次に学習すべきデータに対する結果(ラベル値)が、 結果入力装置113を介し、人手によって、あるいはコンピュータにより入力される。入 力された結果は制御装置110に送られ、制御装置110は、その結果が入力されたデー タを記憶装置109から削除し、その代わりに記憶装置101に記憶させる。以後、第1



の実施形態の場合と同様に、上述の処理が繰り返され、能動学習が進行する。

#### [0066]

図18は、本実施形態の能動学習システムの効果を説明する図である。図において、破線321は従来の能動学習法を用いた場合の正解率の推移を示し、破線322は、第1の実施形態の能動学習システムを用いた場合における正解率の推移を示し、実線323は、グループ生成装置115によって作成されたグループ情報をもとにして次に学習すべきデータを選択する本実施形態の能動学習システムを用いた場合における正解率の推移を示している。グループ生成装置によって生成されたグループの情報をもとにして、次に学習すべきデータを選択する際にお互いのデータがなるべく異なったグループに属するようにデータを選択することで、正解率を早い段階で高くすることができることがわかる。

#### [0067]

なお、本実施形態は、サンプリング重み付け装置102、予測重み付け装置103及び データ重み付け装置104のうちの一部または全部を設けない構成とすることもできる。

#### [0068]

#### 《第9の実施形態》

次に、本発明の第9の実施形態について、図19を参照して説明する。図19に示す能動学習システムは、第8の実施形態の能動学習システムと同様のものであるが、データ選択装置116が新たに設けられ、また、データ統合選択装置の代わりに第1の実施形態の場合と同様のデータ統合装置108及び出力装置112が設けられている点で、第8の実施形態のものと相違する。データ選択装置118は、グループ生成装置115からのグループ情報にしたがって、各学習機械106での予測の対象となる未知データを記憶装置109から選択し、選択された未知データを各学習機械106に送るものである。

#### [0069]

この能動学習システムでは、グループ生成装置 115 で生成されたグループは、データ選択装置 116 に送られる。記憶装置 109 からは未知データがデータ選択装置 116 に送られる。データ選択装置 116 は、なるべく異なったグループに散らばるように未知データが選択して、選択されたデータが、予測のために学習機械 106 に送られる。データ統合装置 108 は、データ重み付け装置 904 で決定された重み付けを適用して、次に学習すべきデータを選択する。この能動学習システムは、第8の実施形態の能動学習システムと同様の効果を奏する。

#### [0070]

なお、本実施形態は、サンプリング重み付け装置102、予測重み付け装置103及び データ重み付け装置104のうちの一部または全部を設けない構成とすることもできる。

#### [0071]

以上説明した能動学習システムは、それを実現するためのコンピュータプログラムを、パーソナルコンピュータやワークステーションなどのコンピュータに読み込ませ、そのプログラムを実行させることによっても実現できる。能動学習を行うためのプログラム(能動学習システム用プログラム)は、磁気テープやCD-ROMなどの記録媒体によってもは、一般に、CPUと、プログラムやデータを格納するためのハードディスク装置と、なモリと、キーボードやマウスなどの入力装置と、CRTや液晶ディスプレイなどのトリと、ボードやマウスなどの入力装置と、CRTや液晶ディスプレイなどのトワークとのインタフェースとなる通信インタフェースとから構成されている。ハードディスク装置、主メモリ、入力装置、表示装置、読み取り装置及び通信インタフェースは、いずれもCPUに接続している。このコンピュータでは、能動学習を実行するためのプログラムを格納した記録媒体を読み取り装置に装着し、記録媒体からプログラムを読み出してハードディスク装置に格納し、あるいはそのようなプログラムをネットワークからダウンードしてハードディスク装置に格納し、その後、ハードディスク装置に格納されたプログラムをCPUが実行することにより、上述した能動学習が実行されることになる。

#### 【図面の簡単な説明】



- 【図1】本発明の第1の実施形態の能動学習システムの構成を示すブロック図である
- 【図2】図1に示すシステムを用いた能動学習法の処理を示すフローチャートである
- 【図3】図1に示すシステムによる能動学習法と従来の能動学習法とにおける学習精度を比較するグラフであって、(a)はヒット率を示すグラフ、(b)はROC曲線を示すグラフ、(c)は正解率の推移を示すグラフである。
- 【図4】本発明の第2の実施形態の能動学習システムの構成を示すブロック図である
- 【図5】図4に示すシステムによる能動学習法と従来の能動学習法とにおける学習精度を比較するROC曲線のグラフである。
- 【図6】本発明の第3の実施形態の能動学習システムの構成を示すブロック図である
- 【図7】図6に示すシステムによる能動学習法と従来の能動学習法とにおける学習精度を比較するROC曲線のグラフである。
- 【図8】本発明の第4の実施形態の能動学習システムの構成を示すプロック図である
- 【図9】図8に示すシステムによる能動学習法と従来の能動学習法とにおける学習精度を比較する正解率推移を示すグラフである。
- 【図10】本発明の第5の実施形態の能動学習システムの構成を示すブロック図である。
- 【図11】図10に示すシステムによる能動学習法と従来の能動学習法とにおける学習精度を比較するROC曲線のグラフである。
- 【図12】本発明の第6の実施形態の能動学習システムの構成を示すブロック図である。
- 【図13】図12に示すシステムによる能動学習法と従来の能動学習法とにおける学習精度を比較するグラフであって、(a)はヒット率を示すグラフ、(b)はROC曲線を示すグラフである。
- 【図14】本発明の第7の実施形態の能動学習システムの構成を示すブロック図である。
- 【図15】図14に示すシステムによる能動学習法と従来の能動学習法とにおける学習精度を比較するグラフであって、(a)はヒット率を示すグラフ、(b)はROC曲線を示すグラフである。
- 【図16】本発明の第8の実施形態の能動学習システムの構成を示すブロック図である。
- 【図17】図16に示すシステムを用いた能動学習法の処理を示すフローチャートである。
- 【図18】図16に示すシステムによる能動学習法と従来の能動学習法とにおける学 習精度を比較する正解率推移を示すグラフである。
- 【図19】本発明の第9の実施形態の能動学習システムの構成を示すブロック図である。

#### 【符号の説明】

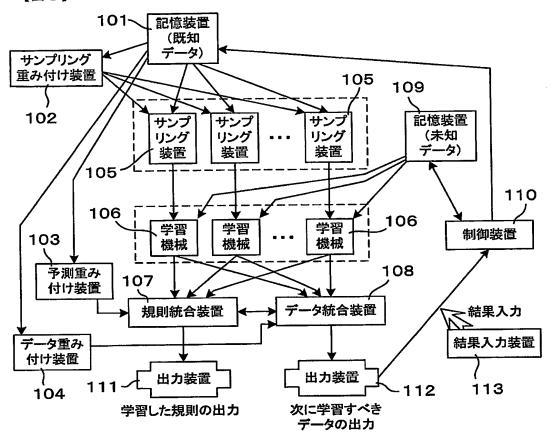
#### [0073]

- 101,109 記憶装置
- 102 サンプリング重み付け装置
- 103 予測重み付け装置
- 104 データ重み付け装置
- 105 サンプリング装置
- 106 学習機械

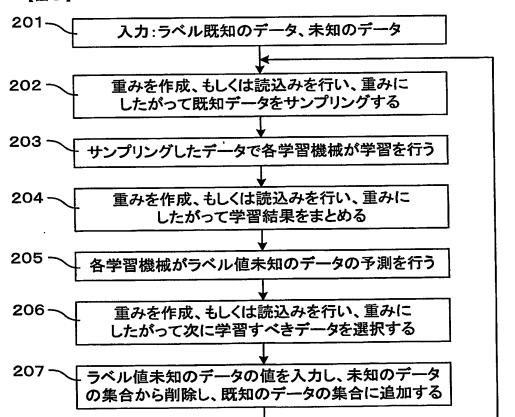
1 0 7	規則統合装置	
108	データ統合装置	
1 1 0	制御装置	
111,	112 出力装置	
1 1 3	結果入力装置	
1 1 4	データ統合選択装置	
1 1 5	グループ生成装置	
1 1 6	データ選択装置	
2 0 1 ~	$-207, 211 \sim 218$	ステップ



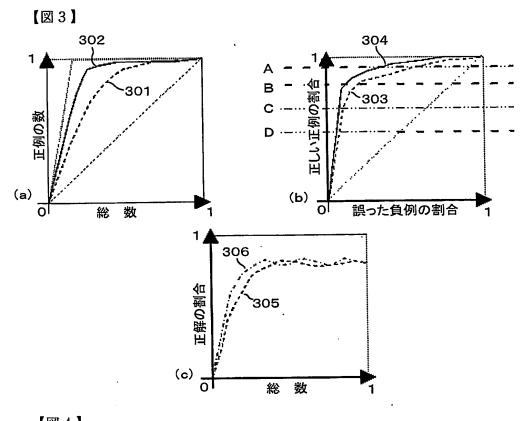
# 【書類名】図面【図1】

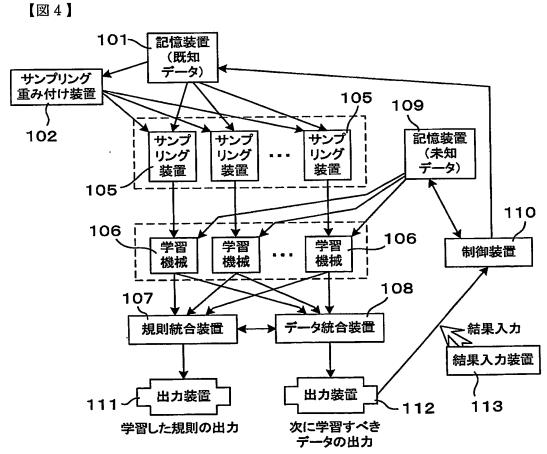


【図2】



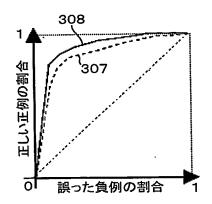




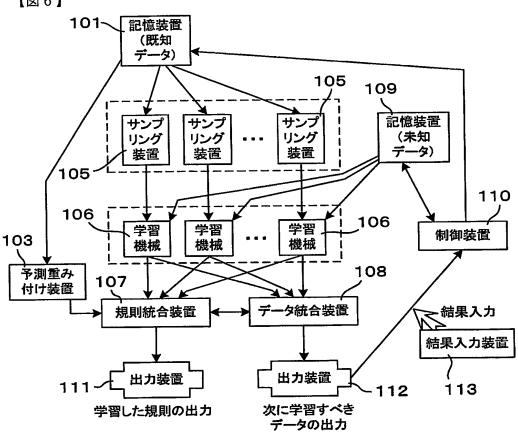




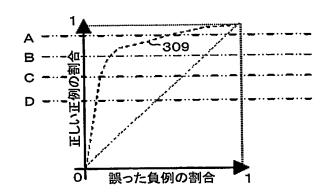
【図5】



【図6】

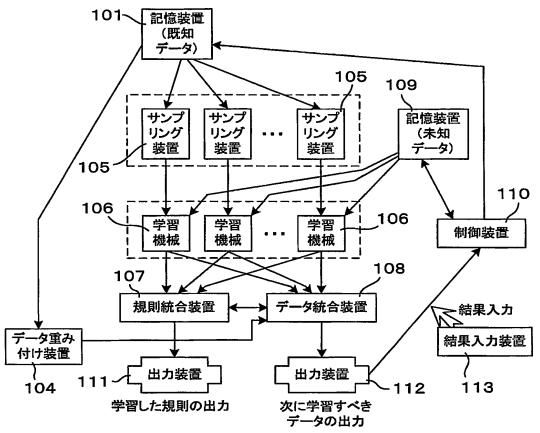


【図7】

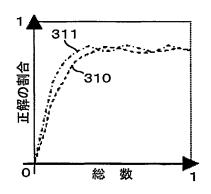






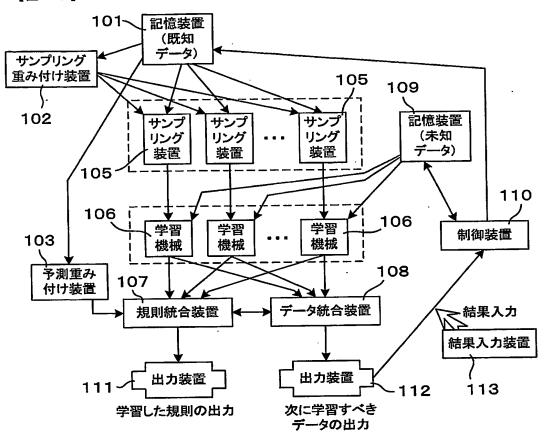


【図9】

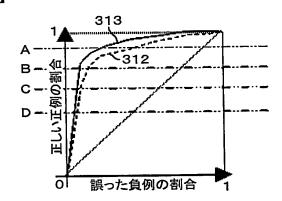




#### 【図10】



## 【図11】

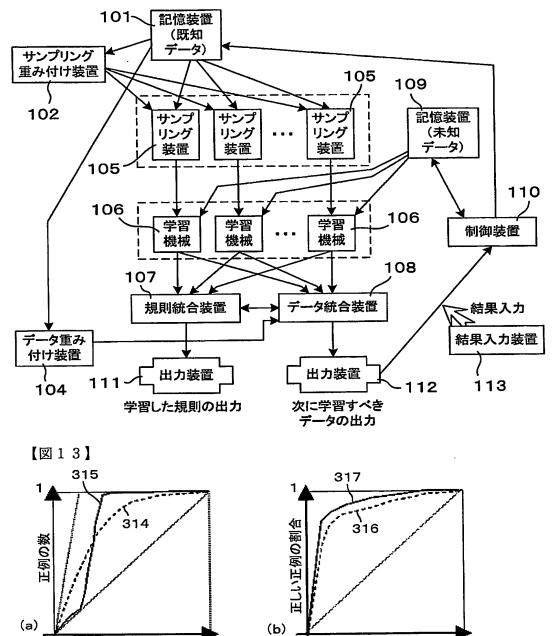






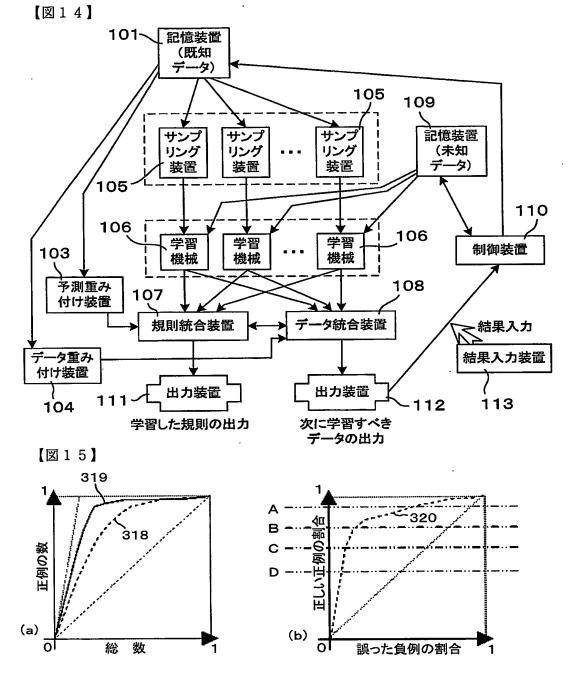
総

数



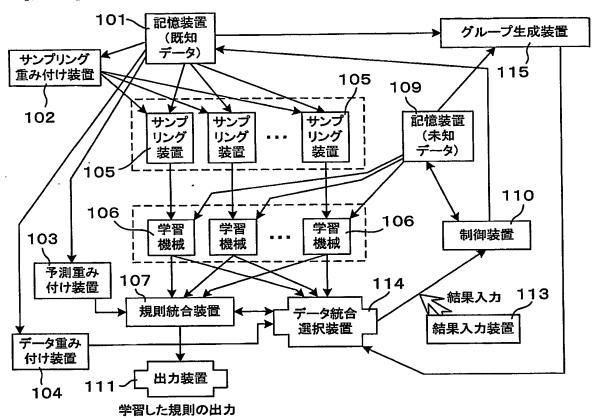
誤った負例の割合

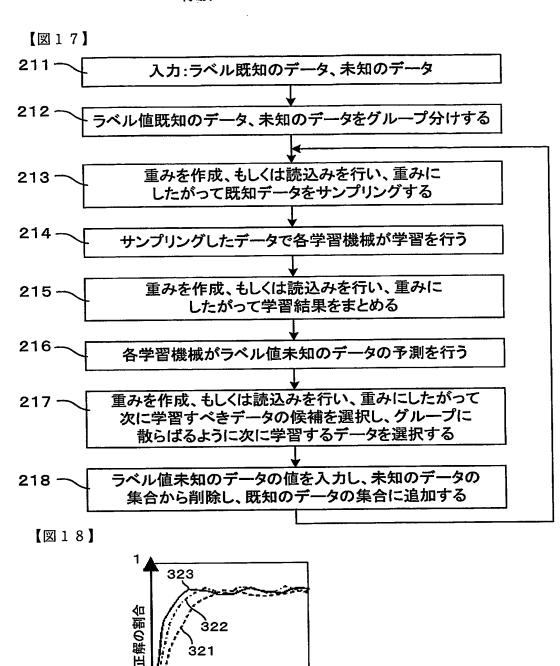










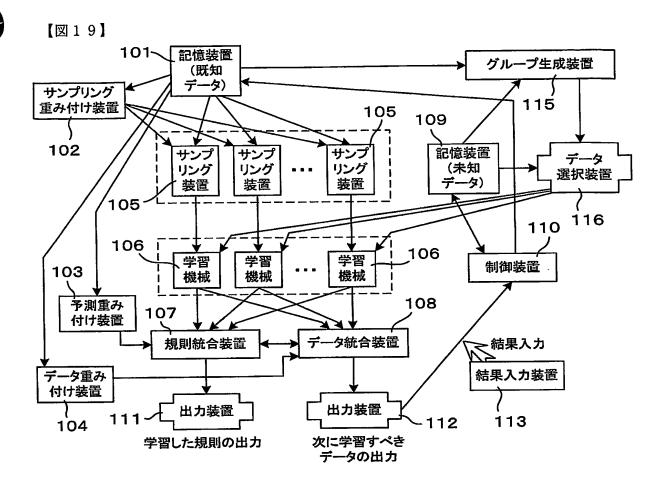


**321** 

総

数







#### 【書類名】要約書

【要約】

【課題】 能動学習法の精度を向上させつつ、利用者の意思では制御できなかった精度や、興味のあるデータを先に抜き出すという機能を提供する。

【解決手段】 既知データをサンプリングし、既知データに対しては複数の学習機械106で独立に学習を行い、未知データに対しては次に学習すべきデータを選択する能動学習システムにおいて、既知データをサンプリングする時に重み付けを行うためのサンプリング重み付け装置102と、学習機械106の学習結果を統合する際に重み付けを行うため予測重み付け装置103と、次に学習すべきデータを選択するときに重み付けを行うためデータ重み付け装置104と、を設ける。各重み付け装置においては、データ数に極端に偏りが発生しているときに、その比重を重くするように重み付けを行う。

【選択図】 図1



出願人履歴情報

識別番号

[000004237]

1. 変更年月日 [変更理由] 住 所 氏 名 1990年 8月29日 新規登録 東京都港区芝五丁目7番1号 日本電気株式会社

# This Page is Inserted by IFW Indexing and Scanning Operations and is not part of the Official Record.

# **BEST AVAILABLE IMAGES**

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

BLACK BORDERS
☐ IMAGE CUT OFF AT TOP, BOTTOM OR SIDES
☐ FADED TEXT OR DRAWING
☐ BLURRED OR ILLEGIBLE TEXT OR DRAWING
☐ SKEWED/SLANTED IMAGES
☐ COLOR OR BLACK AND WHITE PHOTOGRAPHS
GRAY SCALE DOCUMENTS
LINES OR MARKS ON ORIGINAL DOCUMENT
REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY
□ other:

# IMAGES ARE BEST AVAILABLE COPY.

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.